08 | 模型优化（上）：怎么用特征工程提高模型效率？

2021-09-15 黄佳

《零基础实战机器学习》 课程介绍 >

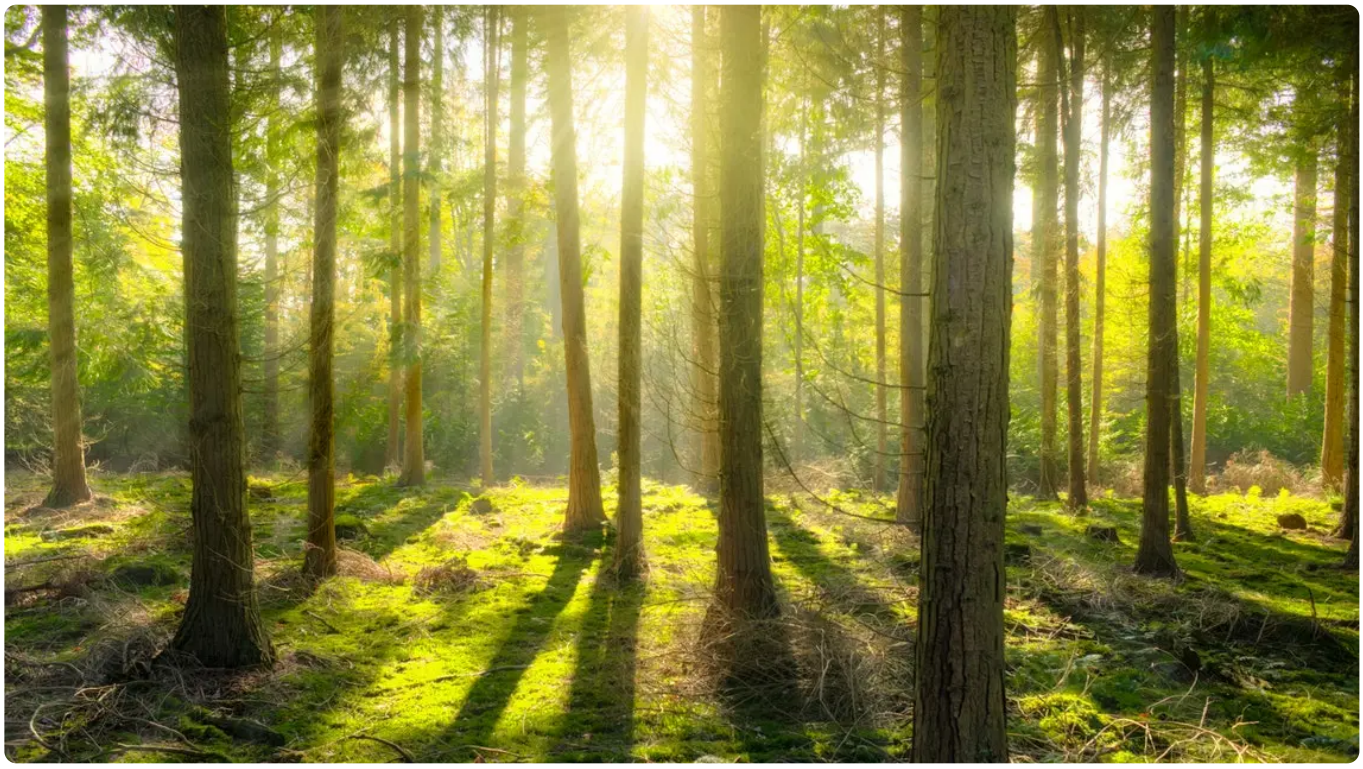

讲述：黄佳
时长 30:45 大小 28.17M

你好，我是黄佳。欢迎来到零基础实战机器学习。

经历过了前面几个项目实战，你是不是想告诉我说，佳哥，机器学习的流程也很简单，似乎只要选个模型并重复 5 个步骤，就可以搞定任何数据集。

看起来是这样，不过也没有这么简单。模型，谁都可以构建，但是，如何让模型的性能更优，才是我们真正的考验。今天，我们就来谈一个与模型优化相关的重要内容，也就是特征工程。

人们常说，**数据和特征决定了机器学习的上限，而模型和算法只是无限逼近这个上限而已。**请你想一想，在那些给定数据集的机器学习竞赛中，高手们为什么能在数据集相同、

模型也类似的前提下，让模型达到一个很高的预测准确率？其实，就是因为他们大都通过漂亮的特征工程，提高了机器学习的上限。

特征工程说起来很简单，就是指**优化数据集的特征，使机器学习算法更起作用的过程，**但用好特征工程并不容易。对于很多初学者来说，常常感觉特征工程实现起来种类繁多，五花八门，不知道怎么下手。今天这节课我就来带你解决这一难题。

根据我这么多年的经验和理解，特征工程其实是有章可循的。总结起来，几乎所有的特征工程，都逃不开三个基本的思路：**特征选择，特征变换和特征构建。**只要你掌握了它们，以后每拿到一个新的问题和新的数据集时，都可以从这三个维度去分析。这样，你就不至于无从下手，你的特征工程也不会有大的偏差。

那你肯定很想了解它们都是怎么回事儿，别着急，现在我就跟你一一道来。

特征选择

其实，在一个数据集中，每个特征在标签预测或分类过程中发挥的作用其实都不同。对于那些没作用和作用小的数据，我们就可以删掉，来降低数据的维度，节省模型拟合时的计算空间。这就是特征选择。

那么，怎么看哪个特征作用大，哪个作用小？我给你介绍一种常用的方法：相关性热力图。就拿我们上节课的项目来说，在我们预测 LTV 的数据集中，一共有 3 个特征，分别是“R 值”、“F 值”和“M 值”，还有 1 个标签“LTV”。这时候，我们就可以通过相关性热力图来看看，哪些特征和标签的相关性更高。

具体的实现过程，就是用 corr() 方法求出数据集中所有字段之间的相关性，然后用 seaborn 的 heatmap 方法，将它以热力图的形式呈现出来：

复制代码

```
# 对所有的标签和特征两两显示其相关性热力图(heatmap)
import seaborn as sns
sns.heatmap(df_LTV.corr(), cmap="YlGnBu", annot = True)
```

输出如下：

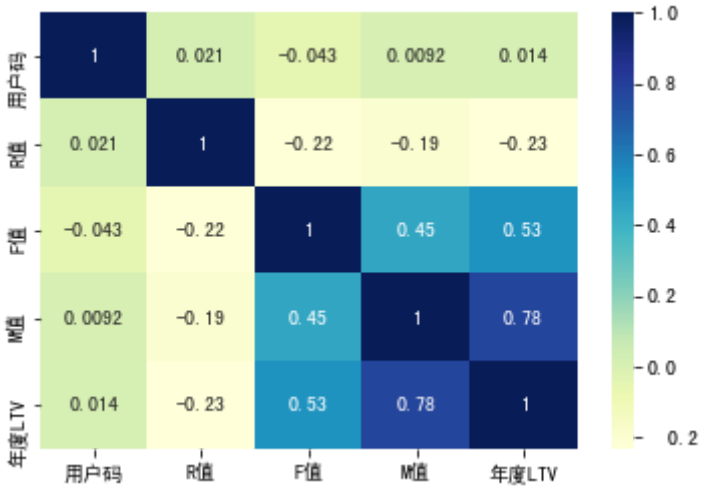

那么怎么去看这个相关性热力图呢？

首先，我们只要聚焦于 LTV 标签和 R、F、M 三个特征之间的关系就可以了，用户码这个字段和 LTV 肯定是不相关的。

然后我们再来看这张图中方格里的数字，这类数字叫做皮尔逊相关系数，表示两个变量间的线性相关性，数值越接近 1，就代表相关性越大。那么，自己和自己的相关性当然就是 1 了。

接下来，你需要知道的是，相关性是有正负的。正值说明是正相关，负值说明是负相关，从图中我们看到，R 值和年度 LTV 的相关性为 -0.23，就表明这个数据集中新进度（R）数字越大，年度 LTV 就越小。你可以想一想这是为什么。

此外，我们还会发现，M 值、F 值和 LTV 的相关度比较高，而 R 值和 LTV 的相关度比较低。这时候，我们就可以选择丢弃“R 值”这个字段。这就是一个特征选择。

复制代码

```
X_train_less_feature = X_train.drop(['R值'], axis=1) #特征训练集
X_valid_less_feature = X_valid.drop(['R值'], axis=1) #特征验证集
model_lr_less_feature = LinearRegression() #创建线性回归模型
model_lr_less_feature.fit(X_train_less_feature, y_train) #拟合线性回归模型
print('测试集上的R平方分数-线性回归: %0.4f' % r2_score(y_valid, model_lr.predict(X
print('测试集上的R平方分数-少R值特征的线性回归: %0.4f' % r2_score(y_valid, model_lr_
```

输出结果如下：

```
测试集上的R平方分数-线性回归： 0.4410
测试集上的R平方分数-少R值特征的线性回归： 0.4356
```

复制代码

在这段代码中，我们用同样的线性回归模型进行拟合、评估，唯一的区别就是特征减少了一个 R 值。你会发现，在这种情况下训练出来的模型，得分会低一点点，不过变化并不太显著，这就说明“R 值”这个特征对函数最终的性能影响确实不大。但是，如果你丢掉的是 F 值或 M 值，那么模型的分数将显著降低。

尽管如此，我还是要说明一下，在这个项目的模型训练中，我并不建议你进行这样的特征选择。因为原始的特征数目已经很少了，要是再把 R 值这样的特征丢弃，显然不合逻辑。我刚才做这样的尝试，只是想为你展示特征选择的思路。

在上面的过程中，我们通过“相关性热力图”，观察了每个特征和标签之间的关系，并手工选择了特征。那么你可能会问，难道没有工具可以帮我们自动进行特征选择吗？当然有。

在 sklearn 的 feature_selection 模块中，有很多自动特征选择工具。这里我给你介绍一个常用的单变量特征选择工具，SelectKBest。SelectKBest 的原理和使用都非常简单，它是对每个特征和标签之间进行统计检验，根据 X 和 y 之间的相关性统计结果，来选择最好的 K 个特征，并返回。

对于我们的 LTV 预测数据集来说，我们可以这样调用 SelectKBest 来选择特征。

```
from sklearn.feature_selection import SelectKBest, mutual_info_regression  #导
selector = SelectKBest(mutual_info_regression, k = 2) #选择最重要的两个特征
selector.fit(X, y) #用特征选择模型拟合数据集
X.columns[selector.get_support()] #输出选中的两个特征
```

复制代码

输出如下：

```
Index(['F值', 'M值'], dtype='object')
```

复制代码

在调用 SelectKBest 的过程中，我们是指定了参数 score_func = mutual_info_regression，其中，mutual_info_regression 是用于对连续型标签进行特征评分。如果标签是离散型的，那么就是分类问题，我们就要用过 mutual_info_classif 来评分了。

从输出的结果来看，F 值和 M 值的分数比 R 值高。所以，在 K=2 的情况下，我们就需要在这 3 个特征中舍弃一个，这时候 R 值就要被舍弃。这个结果和我们前面观察到的一致。

总体来说，单变量特征选择比较直接，速度快，并且独立于模型。但是，你有没有想过这种做法可能会有一个问题？那就是，如果一个特征表面上和标签不大相关，但是在与另一个特征组合之后，才会具有信息量，那么上面的做法可能会让你错误地舍弃这个特征。

那么，有没有一种考虑了各个特征之间的组合后，才做出特征选择的工具呢？有。不过，这样的多变量组合型特征选择工具必须结合具体的模型存在，也就是说，当所有特征都被输入模型进行拟合时，在这个过程中才能评估出最不重要的特征，然后再进行特征选择。

在 sklearn 的 feature_selection 里，有下列几种在拟合特定模型时进行特征选择的工具，你可以选择使用：

变量组合型特征选择工具	说明
RFE工具	递归特征消除，英文是recursive feature elimination。机器每次训练后，都去除一个最不重要的特征，然后用新的特征集继续训练模型，直到达到想要的特征数量为止，比如说两个。
SelectFromModel工具	从模型中选择特征，原理和RFE类似，区别在于它是基于重要性权重的阈值来选择特征。
SequentialFeature Selector工具	顺序特征选择，英文是Sequential Feature Selection，通过不断地观察R-square等指标自动识别重要变量，在每次训练的时候增加或者减掉一个特征来拟合模型。顺序特征选择有正向选择和反向选择两种。正向选择从模型中最重要的预测变量开始，逐步添加特征。反向选择从模型中的所有预测变量开始，逐步删除最不重要的特征。

极客时间

除了这些特征选择工具，我认为“数据降维”也可以归入到特征选择中。当然，也有人把降维视为一种独立的特征工程类型。

那什么是数据降维呢？其实就是通过特定算法，把多维特征压缩成低维的特征，也就是通过算法实现特征选择，减少特征的数目。常见的降维算法有两种：主成分分析法（PCA）和线性判别分析（LDA）。PCA 是一种无监督的降维方法，而 LDA 是一种有监督的降维方法。出于咱们的课程定位，这些降维算法我们并不会过多涉及。

另外，还有一种方式，就是用深度学习来进行特征选择，这在计算机视觉领域十分普遍。因为深度学习具有自动学习特征的能力。就拿图片识别来说，当图片被输入到卷积神经网络后，网络会自动形成一条条特征通道，选择提取有用的信息来进行最终的目标模型训练。

不过，神经网络中的这些特征通道是怎么形成的，我们目前还没有很好的方式用数学手段去推导、确定，它对于我们来说就像一个黑箱。

总而言之，特征选择的目标是，尽量保持对模型训练有效的信息，与此同时减少数据集的特征数量。

除了特征选择外，还有一种特征工程是在原有特征的基础上进行加工，没有减少特征数，这就是特征变换。

特征变换

特征变换的整体目标是让原始特征变得机器学习模型可用，甚至是更好用。

要搞清楚特征变换，我们就得先了解一下特征的类型。其实，特征和标签一样，也分为连续和离散两类。像分数、点击量这些，就属于连续特征（continuous feature）；而离散特征（discrete feature），也叫类别特征（categorical feature），像男生、女生，或者说北京、上海、深圳、广州等等，这些都属于离散特征。

不同的特征类型，有不同的特征变换方式。对连续特征来说，我们最常见的特征变换就是特征缩放（feature scaling），也就是改变特征的分布或者压缩特征的区间。因为有很多模型都喜欢范围比较小、分布有规律的数据，比如采用梯度下降方法求解最优化的模型，较小的数值分布区间能够提升收敛速度，还有 SVM、KNN、神经网络等模型，都要求对特征进行缩放。

对数值型特征的缩放

在 sklearn 中，特征缩放方法很多：

特征缩放工具	说明
StandardScaler工具	即“标准化缩放”，是对数据特征分布进行转换，目标是使其符合正态分布（均值为0，方差为1）。对于某些模型，如果数据特征不符合正态分布的话，就会影响机器学习效率。
MinMaxScaler工具	是把特征的值压缩到给定的最小值和最大值之间，通常在0和1之间，有负值的话就是-1到1，因此也叫归一化。归一化不会改变数据的分布状态。在sklearn中，通过MinMaxScaler进行标准化缩放。某些模型，比如神经网络，就非常喜欢归一化之后的特征数据。
RobustScaler工具	基于百分位数的缩放，能消除数据中离群值的影响，但转换后，特征值的结果范围会比之前的更大，所以在RobustScaler之后，通常还会结合归一化缩放器一起使用，再把数据压缩一下。
Normalizer工具	即“规范化缩放”，它是将样本缩放为具有单位范数的过程，这可能仅适用于某些各个维度都是One-Hot编码的数据集，应用场景较少。

极客时间

下面是各个特征缩放方法从原始特征到新特征的缩放效果图，你可以看看：

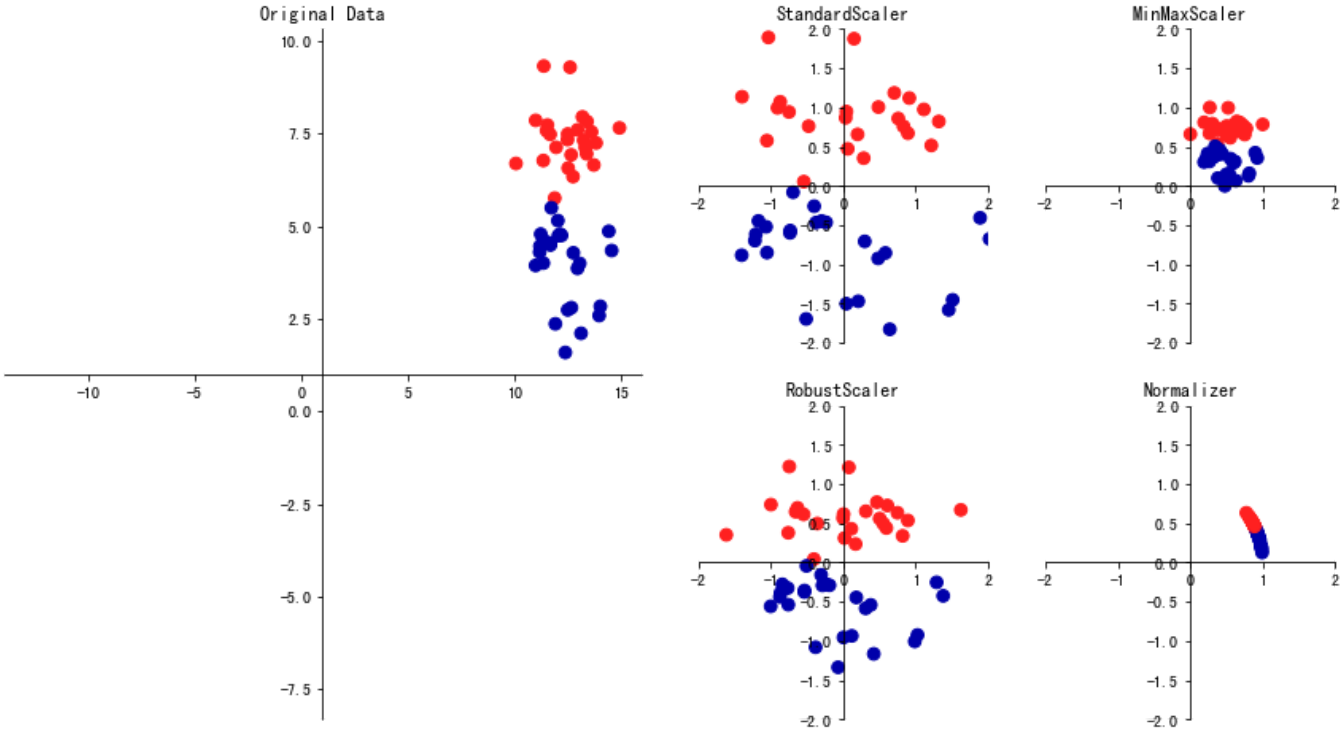

四种特征缩放器效果图

下面，我们选择其中最常见的两个特征缩放工具 StandardScaler 和 MinMaxScaler，来预测用户 LTV，比较一下它们的优劣。你要注意，这里所谓的优劣，仅针对于这个特定数据集和特定问题而言。

由于大部分的代码和实战中介绍过的相同，我这里就不再重复了。下面我只是展示和特征工程相关的代码，你可以在这里下载到完整的代码。

首先，我们调用 StandardScaler，进行数值特征的标准化缩放，这个缩放将形成正态分布的新特征。

```
from sklearn.preprocessing import StandardScaler #导入标准化缩放器
scaler = StandardScaler() #创建标准化缩放器
X_train_standard = scaler.fit_transform(X_train) #拟合并转换训练集数据
X_valid_standard = scaler.transform(X_valid) #转换验证集数据
X_test_standard = scaler.transform(X_test) #转换测试集数据
```

在上面的代码中，你要特别注意，在创建标准化缩放器之后，我们对于训练集使用了 fit_transform 这个 API，这是 fit 和 transform 两个 API 的整合，它的意思是先根据训练集拟合数据，找到合适的标准化参数，然后再把参数应用在训练集上，给数据做缩放。

而在验证集和测试集上，我们只使用 transform 这个 API，来通过从训练集中得到的参数，来转换数据，这个步骤中就没有 fit 的过程，这是因为对于模型来说，验证集和测试集是新的看不见的数据，因此在训练之前或训练期间它是不应该被访问的，使用来自验证集和测试集的任何信息都属于数据泄露，会导致评估性能的潜在偏差。

这也就是为什么特征缩放必须在拆分完训练集和测试集后进行，因为它的参数只能来自训练集的数据。

然后，我们用缩放后的特征训练模型，得到一个随机森林模型 model_rfr_standard。这里的 rfr 是一个缩写，代表 random forest refressor，也就是随机森林回归。

```
model_rfr_standard = RandomForestRegressor() #创建随机森林回归模型
model_rfr_standard.fit(X_train_standard, y_train) #拟合随机森林模型
```

讲完了 StandardScaler，我们再用 MinMaxScaler 来预测用户 LTV。进行数值特征的归一化缩放。所谓“归一化”，就是把特征的值压缩到给定的最小值和最大值，比如 0-1 之间。如果有负值的话，那就是 -1 到 1 之间。

与标准化的过程相同，在对验证集和测试集进行归一化时，我们也应该按原样，使用先前从训练集中获得的归一化参数，而不是在验证集和测试集上重新计算它们。

复制代码

```
from sklearn.preprocessing import MinMaxScaler #导入归一化缩放器
scaler = MinMaxScaler() #创建归一化缩放器
X_train_minmax = scaler.fit_transform(X_train) #拟合并转换训练集数据
X_valid_minmax = scaler.transform(X_valid) #转换验证集数据
X_test_minmax = scaler.transform(X_test) #转换测试集数据
```

然后，我们用缩放之后的特征训练模型，得到一个随机森林模型 model_rfr_minmax。

复制代码

```
model_rfr_minmax = RandomForestRegressor() #创建随机森林回归模型
model_rfr_minmax.fit(X_train_minmax, y_train) #拟合随机森林模型
```

那到这里，我们就得到了两个随机森林模型：model_rfr_standard 和 model_rfr_minmax。我们拿这两个模型，和不使用特征缩放训练出来的模型，整体做一个对比，看看这三种模型在验证集上的分数怎么样。这里我把评估的结果用柱状图来展示了（对应的代码你可以参见这个链接）：

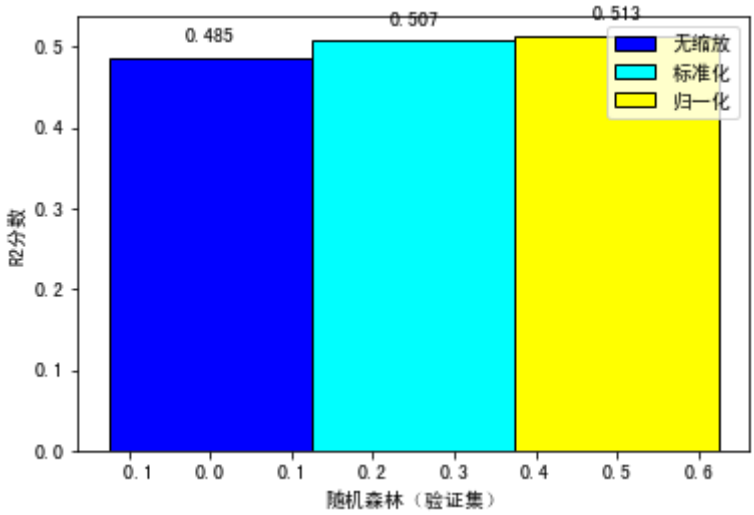

可以看到，对于预测用户 LTV 这个项目来说，采用特征缩放，尤其是 MinMaxScaler，模型在验证集上会得到较优的结果。

你也许会问，数值型特征常见的变换是特征缩放，那么类别型特征呢？其实对于类别型特征来讲，最常见的变换方式是通过虚拟变量（也叫哑编码或者哑变量）把机器不能读取的类别文本，转换成一个个的 0、1 值。

对类别型特征的变换：虚拟变量和独热编码

把类别特征转换成机器可以读取的编码，也非常简单。如果数据表中的字段值是“男”、“女”这样的数据，我们就用下面的代码直接转换成 0、1 值即可。

复制代码

```
df['性别'].replace(to_replace='女', value=0, inplace=True)
df['性别'].replace(to_replace='男', value=1, inplace=True)
```

对于两个以上的分类，pandas 编码有一种非常简单的方法，就是 get_dummies 函数。get_dummies 函数会自动变换所有具有对象类型（比如字符串）的列或所有分类的列，而分类特征的每个可能取值都会被扩展为一个新特征，并且每一个新特征只有 0、1 两种取值。这个过程就是虚拟变量的生成过程，你看看这张图就会比较清楚了。

Color
Red
Red
Yellow
Green
Yellow

Red	Yellow	Green
1	0	0
1	0	0
0	1	0
0	0	1
0	1	0

对于自然语言处理中的分词过程，这样的编码转换是必须的

下面我们就把上一个项目中的订单数据集里的“城市”转化为虚拟变量。对于这一步，其实我在之前的课程中给你留过作业，并给出了“提示”，这里我就用和提示不大一样的代码，来实现相同的功能。

复制代码

```
# 把多分类字段转换为二分类虚拟变量
category_features = ['城市'] #要转换的特征列表
df_sales = pd.get_dummies(df_sales, drop_first=True, columns=category_features
df_sales #显示数据
```

输出如下：

订单号	产品码	消费日期	产品说明	数量	单价	用户码	城市_北京	城市_广州	城市_成都	城市_深圳	城市_苏州	城市_西安
536374	21258	6/1/2020 9:09	五彩玫瑰五支装	32	10.95	15100	1	0	0	0	0	0
536376	22114	6/1/2020 9:32	茉莉花白色25枝	48	3.45	15291	0	0	0	0	0	0
536376	21733	6/1/2020 9:32	教师节向日葵3枝尤加利5枝	64	2.55	15291	0	0	0	0	0	0
536378	22386	6/1/2020 9:37	百合粉色10花苞	10	1.95	14688	1	0	0	0	0	0
536378	85099C	6/1/2020 9:37	橙黄香槟色康乃馨	10	1.95	14688	1	0	0	0	0	0
...	...	...	...	...	...	...	...	...	...	...	...	...
581585	21684	6/9/2021 12:31	产品说明掩码	12	5.00	15804	0	0	0	1	0	0
581585	22398	6/9/2021 12:31	产品说明掩码	12	499.00	15804	0	0	0	1	0	0
581585	23328	6/9/2021 12:31	产品说明掩码	4	58.00	15804	0	0	0	1	0	0
581585	23145	6/9/2021 12:31	产品说明掩码	12	88.90	15804	0	0	0	1	0	0
581585	22466	6/9/2021 12:31	产品说明掩码	12	78.00	15804	0	0	0	1	0	0

可以看到，原来的城市字段，变成了多个二分类字段，比如城市 _ 北京、城市 _ 成都等，并且每个字段只有 0、1 值，这样的编码格式就可以被机器识别。

这里呢，我要请你特别注意一下 drop_first 这个参数。这个参数实际上控制着 get_dummies 函数返回的结果，值为 True 返回结果是虚拟变量（Dummy Variable），值为 False 则返回独热编码（ One Hot Encoding）。

独热编码与虚拟变量非常相似，它们的不同之处在于：在虚拟编码方案中，当特征具有 m 个不同类别标签时，我们将得到 m-1 个二进制特征，作为基准的特征被完全忽略；而在独热编码方案中，我们将得到 m 个二进制特征。因此，你仔细观察上面 get_dummies 的结果，就会发现“城市 _ 上海”这个特征没有被生成。而如果你把 drop_first 设为 False，“城市 _ 上海”就会出现。

那么，为什么要有这样的区别呢？主要有两个原因。第一个原因是，如果有 N 个特征，并且前 N-1 个特征的值是已知的，那么第 N 个特征的值也就知道了。因此，独热编码有冗余，虚拟变量没有冗余。举个例子，对于用户来说，如果其它所有城市的值都是 0，唯独“上海”这个字段的值不知道，我们自然就能推知这个用户是属于上海这个城市，因为这是仅有的可能性了。

第二个原因是，独热编码的这种冗余会导致共线性问题，也就是自变量之间存在高度相关关系，不总是相互独立的，从而使模型参数估计不准确。不过，这也意味着，独热编码可以直接从“1”值看出所对应的类别，而虚拟变量需要进行推理。因此独热编码比较直观，虚拟变量没有那么直观。

那我们应该在什么时候使用虚拟变量，在什么时候使用独热编码呢？如果线性模型有截距项，就使用虚拟变量；如果线性模型无截距项，那么使用独热编码。

此外，在线性模型有截距项的情况下，如果使用正则化，那么也推荐使用独热编码，因为正则化能处理多余的自由度，可以约束参数；如果不使用正则化，那么就使用虚拟变量，这样多余的自由度都被统摄到截距项 intercept 里去了。关于正则化的进一步说明，我会在下一讲详细介绍。

上面所说的虚拟变量和独热编码是对类别型特征的处理，不过在某些情况下，我们还需要把数值型特征离散化。

对数值型特征的离散化：分桶

你可能会奇怪为什么要对特征做离散化处理？这是因为，当特征的数量级跨度过大，而且与标签的关系又非线性的时候，模型可能只对大数量级的特征值敏感，也就是说模型可能会向大特征值的那一侧倾斜。另外，模型的运算速度也会受到影响。

比如说，一个特征的数据值为[3.5, 2.7, 16.9, 5.5, 98]，这里的“98”明显偏离其他数据，很容易影响到模型的效果。这时候我们就可以把这些数值做个离散化，比如把小于 5 的值记为“0”，大于 5 且小于 10 的值记为“1”，大于 10 的值记为“2”，那么[3.5, 2.7, 16.9, 5.5, 98]就可以变成 0、1、2 这样的离散值，也就是[0，0，2，1，2]，这不仅能减弱像“98”这样的异常数据的权重，还能提高模型的运算速度。

我们在这里用的方式呢，就叫做分桶，分桶也叫分箱，就是指将连续型特征离散化为一系列的离散值。而这里的 0、1、2 呢，就是我们说的“桶”或者“箱”了。

对数值进行分桶，我们首先要确定两点：一是桶的数量，二是把什么范围的数据分成一个桶，也就是桶的宽度是多少。在这个过程中，常规的做法有三种：

1. 等距分桶：每个桶的宽度固定，如 0-99，100-199，200-299 等。这种方式适合样本分布比较均匀的情况，如果样本分布不均，就容易出现有的桶多、有的桶少的情况。
2. 等频分桶：每个桶有一样多的样本，但可能出现数值相差很大的样本放在同一个桶的情况。

3. 模型分桶：利用模型找到最佳分桶。比如决策树模型，它本身就具有对连续型特征切分的能力，因此我们可以利用分割点进行特征离散化。再比如聚类模型，可以将连续性特征分成多个类别。在之前的用户画像项目中，我们对 R 值、F 值、M 值进行聚类，就是一种模型分桶操作，即把连续的数值切分成这三维度的离散类别。

到这里，我们就了解了两种特征工的基本思路，一种是通过特征选择减少特征的维度，另一种是通过特征变换加工原始特征。你可能会问我，有没有什么方法能根据原始数据创造出新的特征呢？

自然是有的，这就是第三种特征工程类型：特征构建。

特征构建

特征构建是整个特征工程领域最具创造力的部分，也是我觉得在数据预处理环节中最有意思的地方。因为它完全没有一定之规，全凭借你的经验、领域知识和创造力。就像我们在获客关的项目实战里，从原始的订单数据集中，我们经过整理和组合原始数据，求出了三个完全不存在于原始数据集中的新值：R 值、F 值和 M 值，**这就是一个典型的特征构建。**

为什么我们知道要构建这三个值？就是因为我们具有运营领域的经验和相关知识，知道 R 值、F 值和 M 值对用户分组画像是重要的因子，能够输入到聚类模型和回归模型中去。

所以，要想把原始数据集中的特征工程做好，就要不断积累经验和知识，展开自己的想象力，看看可以构建出什么样有用的新特征，能让机器学习模型学得更好。

这里我再给你举一个例子。假设我们现在有一个航班的旅客订单信息数据集，记录了几年内每一天航班的旅客订票情况。通过这个数据集，我们要帮航空公司构建一个模型，来预测未来某天的客流量。那么，你能想到什么特征工程方法，有可能提高模型的效率？

其实，我们可以根据“订单日期”这个字段，再人工添加一个新字段，来**标明每一天的具体航班是在国家公休假日的之前、之中还是之后，或并不靠近公休假日。**这个方法，其实是把与预测客流量这个任务的相关先验知识编码到了特征中，以辅助机器学习算法理解为什么流量会出现可能的波动。

当然，添加一个新特征并不意味着机器学习算法肯定会用到它，即使模型发现假日信息和客流量没啥关联，那也无伤大雅。但是，如果真的有关联，这个新特征就会提高模型的预

测准确率，尤其是当预测未来公休假日附近的客流量时，会更准。

为了让你进一步理解特征构建的作用，我再用一个例子，通过程序代码和示意图来直观地给你进行展示。这次，我们读入一个简单的数据集“特征构建示意数据集”（你可以在这里下载数据集），来看看特征 X 和标签 Y 之间的关系，然后思索一下怎么拟合二者。

复制代码

```
import pandas as pd #导入Pandas
import numpy as np #导入NumPy
import matplotlib.pyplot as plt #导入绘图工具
df = pd.read_csv('特征构建示意数据集.csv') #导入数据
plt.scatter(df.X, df.Y) #X，Y散点图
```

输出显示，这个数据集中的特征 X 和标签 y 呈现一种符合回归模型的趋向。

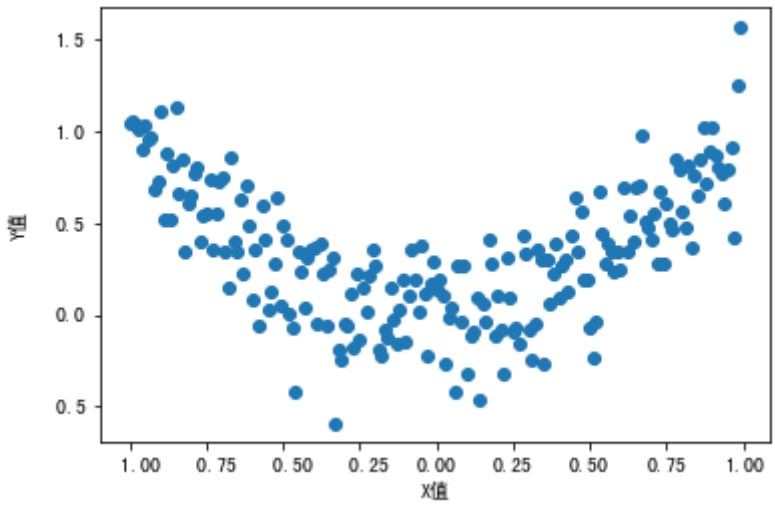

如果我们用线性回归进行建模，就会得到一个线性回归模型：

复制代码

```
from sklearn.model_selection import train_test_split #导入train_test_split
df_x = df['X'].to_frame() #特征集
df_y = df['Y'] #标签集
X_train, X_test, y_train, y_test = train_test_split(df_x,df_y,test_size=0.3, r
from sklearn.linear_model import LinearRegression #导入LinearRegression
model = LinearRegression() #创建模型
model.fit(X_train, y_train) #拟合模型
plt.scatter(df.X, df.Y) #散点图
plt.plot(X_test, model.predict(X_test),linestyle='--', color = 'red') #显示拟合
```

输出这个模型，可以看到这个回归线并不能很好地拟合从 X 到 Y 的关系：

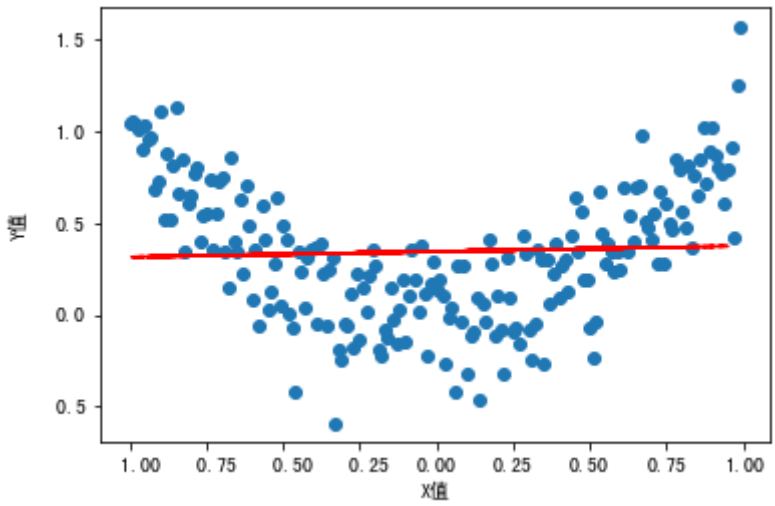

那怎么办呢？其实，我们从图中可以观察到，X-Y 之间的关系其实更接近多项式回归（polynomial regression）中的二项式回归，也就是说，Y 是 X 的二次函数。那么，我们就在 X 的基础上做个平方，构建出一个新特征。

复制代码

```
X2_train = X_train.copy() #新特征训练集
X2_test = X_test.copy() #新特征测试集
X2_train['X2'] = X2_train['X']**2 #构建新特征X2
X2_test['X2'] = X2_test['X']**2 #构建新特征X2
model2 = LinearRegression() #创建新模型
model2.fit(X2_train, y_train) #拟合新模型
plt.scatter(df.X, df.Y) #散点图
plt.scatter(X_test, model2.predict(X2_test), linestyle='--', color = 'red') #
```

这里，我们还是用一样的模型来拟合，并显示原始特征 X 和预测值之间的关系。这时候我们发现，拟合曲线更趋近于 X 和 Y 的真实关系：

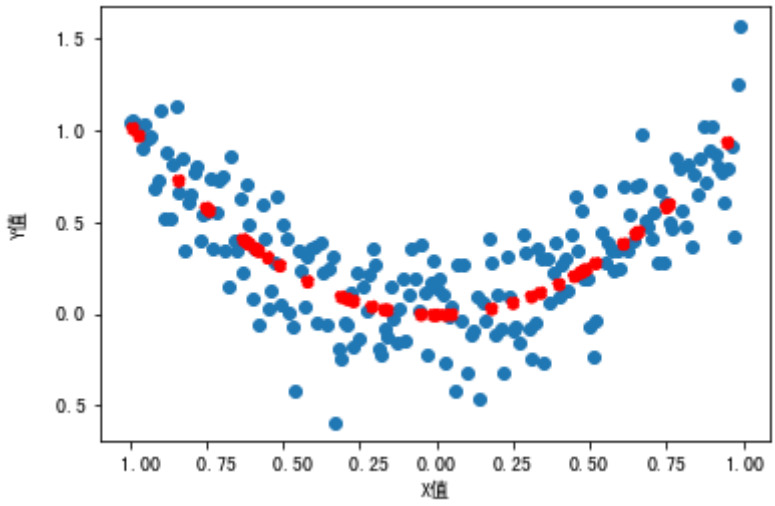

是不是很奇妙呢？希望通过这个小例子，你能理解：在实践中，我们所使用的特征，以及特征与方法之间的匹配，通常都是让机器学习模型能够有良好表现的最重要因素。

总结一下

好了，这节课到这里就结束了，我给你总结了三类重要的特征工程。其中，特征选择可以减少特征的维度，特征变换则能把原始特征塑造的更容易被机器学习模型使用，特征构建则需要你激发极大的创造力，以原始数据为基础去发现对建模有用的新特征。

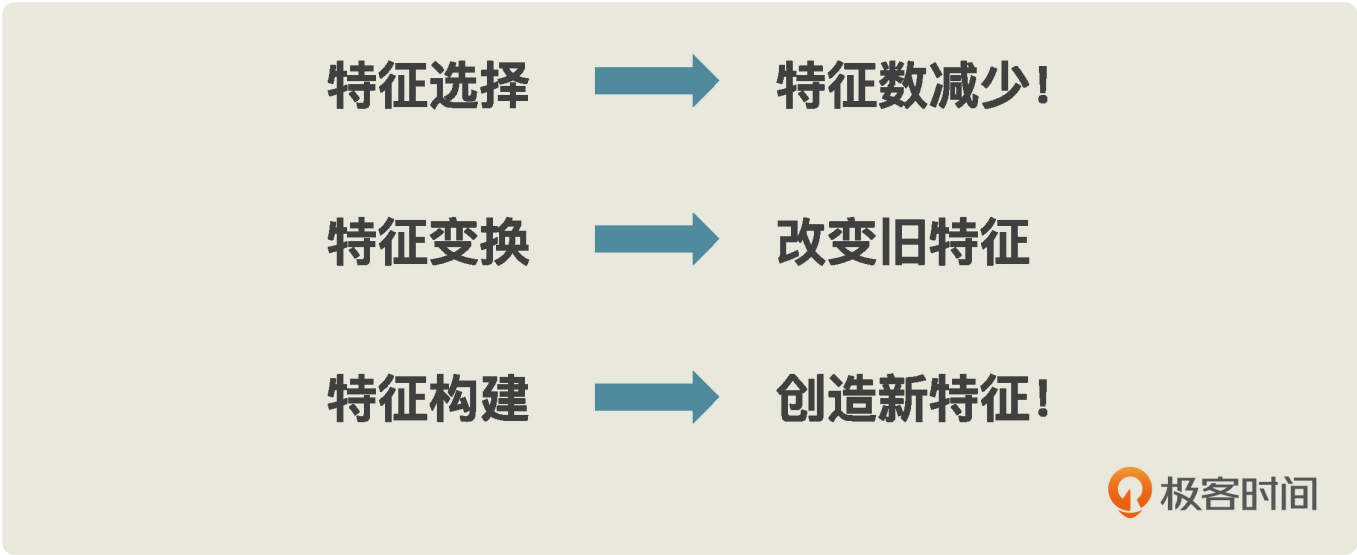

在这一讲中，我特别为你示范了不少精巧的特征工程小示例，所有的代码你都可以在这里找到。不过师傅领进门，修行在个人，更多特征工程的知识和应用，还有待于你在实践中去继续挖掘。

思考题

那么，这一讲我给你留三道思考题：

1. 我在前面使用了 StandardScaler 工具和 MinMaxScaler 工具做特征缩放，请你用一下别的特征缩放器，看看适不适合我们这个数据集。

2.Sklearn 的 OneHotEncoder 工具和 Pandas 的 get_dummies 类似，也可以把整个数据集的字段或者指定的特征字段转换为虚拟变量。请你试一试这个工具。

提示：这个题目较难，涉及数组形状变换。如果遇到麻烦，可以试着上网搜索一下解决方案。

复制代码

```
from sklearn.preprocessing import OneHotEncoder #导入OneHotEncoder工具
encoder = OneHotEncoder(sparse=False)
...
df_city = pd.DataFrame(df_city, columns=encoder.get_feature_names())
...
```

OneHotEncoder 输出的结果：

用户码	x0_上海	x0_北京	x0_广州	x0_成都	x0_深圳	x0_苏州	x0_西安
15100	0.0	1.0	0.0	0.0	0.0	0.0	0.0
15291	1.0	0.0	0.0	0.0	0.0	0.0	0.0
15291	1.0	0.0	0.0	0.0	0.0	0.0	0.0
14688	0.0	1.0	0.0	0.0	0.0	0.0	0.0
14688	0.0	1.0	0.0	0.0	0.0	0.0	0.0
...	...	...	...	...	...	...	...

3. 你在工作中用特征工程构建过新特征吗？有没有比较巧妙的特征工程可以给大家分享呢？如果你还没有做过特征工程，那么请你谈一谈学了这节课之后，你对特征工程有怎样的理解。

欢迎你在留言区分享你的想法和收获，我在留言区等你。如果这节课帮到了你，也欢迎你把这节课分享给自己的朋友。我们下一讲再见！

极客时间

本讲重点

特征工程五花八门，我给你归纳成三大块：

1. 特征选择是在减少特征数量的同时尽量保持对模型训练有效的信息，我们介绍了手工选择、单变量特征选择以及基于模型的多变量特征选择工具。
2. 特征变换是让原始特征变得机器学习模型可用、且更好用，我们介绍了特征缩放、虚拟变量和独热编码，以及分桶。
3. 特征构建是整个特征工程领域最具创造力的部分，我们给出了一个从特征 X 创建出新特征 X 方的示例。

分享给需要的人，Ta订阅后你可得 20 元现金奖励

赞 3 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 07 | 回归分析：怎样用模型预测用户的生命周期价值？

下一篇 09 | 模型优化（中）：防止过拟合，模型也不能太精细

精选留言 (2)

写留言

在路上
2021-09-15

佳哥好，我的理解是，特征构建是将数据和经验相结合，提炼数据的特征，提高模型预测的准确度；特征变换是将数据变成可运算的，或者转化成关心的尺度，减少计算资源的消耗；特征选择既可以去掉重复的特征，提高模型预测的准确度，也可以去掉相关度较小的特征，减少计算资源的消耗，但代价是牺牲模型预测的准确度。
get_dummies将城市这一个维度变成了N个维度，是不是可以把N个维度合并，用位来...

展开

作者回复: 如果把N个维度合并，变成一个维度-“城市”1-北京，2-上海，3-苏州，4...，5...，6.... 我想那样是不对的，为什么呢，因为回归模型会认为苏州比上海大，上海比北京大。影响权重的分配。需要全部转换为N个 0 、 1 虚拟变量编码才是正确的做法。

谦

2021-09-15

‘’ 数据和特征决定了机器学习的上限，而模型和算法只是无限逼近这个上限而已 ‘’ ，对这句话深有体会，特征工程，特别是特征构建是核心竞争力，花时间最多的也是数据采集和特征提取。每一次训练的模型预测结果不理想，都要反过去考虑是不是数据样本太片面了，是不是还有更好的特征可以使用，还能不能构建出更好的特征？

展开

作者回复: 是这样的，调包容易，数据的收集和预处理难。需要领域知识和经验，也就是domain knowledge.

1